

19. *Makarov A.M., Postovalov S.S., Ermakov A.S.* Application of integral transforms in algorithms for detecting signals against a background of noise under priori uncertainty using the Mellin's transforms, *2020 International Multi-Conference on Industrial Engineering and Modern Technologies, FarEastCon 2020*, 2020, pp. 927137.
20. *Postovalov S.S., Makarov A.M.* Rezul'taty issledovaniya tochnosti predstavleniya parametricheski periodicheskikh nestatsionarnykh funktsiy yadra integral'nogo preobrazovaniya Mellina [Results of a study of the accuracy of the representation of parametrically periodic non-stationary functions of the kernel of the Mellin integral transform], *Universitetskie chteniya – 2020: Mater. nauchno-metodicheskikh chteniy PGU* [University readings - 2020: Materials of scientific and methodological readings of PSU]. Pyatigorsk, 2020, pp. 22-46.

Статью рекомендовал к опубликованию д.ф.-м.н., профессор Г.В. Куповых.

Макаров Анатолий Михайлович – Пятигорский государственный университет; e-mail: mellin_22@mail.ru; г. Пятигорск, Россия; тел.: 89283746783; кафедра информационно-коммуникационных технологий, математики и информационной безопасности; д.т.н.; профессор.

Ермаков Александр Сергеевич – e-mail: ermakov@cascad-kmv.ru; тел.: 89620206506; кафедра информационно-коммуникационных технологий, математики и информационной безопасности; старший преподаватель.

Makarov Anatoly Mikhailovich – Pyatigorsk State University; e-mail: mellin_22@mail.ru; Pyatigorsk, Russia; phone: +79283746783; the department of ICTMIS; dr. of eng. sc.; professor; ORCID: <https://orcid.org/0000-0002-6338-9493>.

Ermakov Alexander Sergeevich – e-mail: ermakov@cascad-kmv.ru; phone: +79620206506; the department of ICTMIS; senior lecturer; ORCID: <https://orcid.org/0000-0002-7041-9961>.

УДК 004.8

DOI 10.18522/2311-3103-2023-6-88-95

Е.С. Подоплелова, И.И. Князев

МОДИФИКАЦИЯ МЕТОДА ФМЕА ПРИ ПОМОЩИ АЛГОРИТМОВ МАШИННОГО ОБУЧЕНИЯ

Оценка рисков – важная задача в любых сферах, начиная от производства, заканчивая медициной. Риски сопровождают проект, продукт или процесс на всей жизнедеятельности, с момента планирования до его полного прекращения. На каждом из них существуют свои подходы. К ним относится ФМЕА (Failure Mode and Effects Analysis) - анализ видов и последствий отказов. Предлагаемая модель основана на методе ФМЕА, базирующемся на оценке рисков по трем критериям: тяжесть последствий при реализации угрозы и сложность идентификации отказа, вероятность возникновения. Первые два критерия основаны на экспертной оценке, полученной в соответствии с методами искусственного интеллекта. Авторами предложена модификация третьего критерия. В своей работе мы заменили экспертную оценку критерия «вероятность возникновения» моделью машинного обучения, способной спрогнозировать этот показатель на основе статистических данных. Провели первый этап исследования поставленной задачи на открытом датасете NASA о рабочих циклах двигателей до их отказа. Изначально, ставится задача прогнозирования оставшегося количества циклов до отказа, затем мы произвели переход к задаче классификации, определяя, входит ли в зону риска оборудование, в зависимости от его потенциального остатка ресурса. Нашлучший результат дал метод опорных векторов (SVM), точность классификации которого 80%. Целью работы является создание модели оценки рисков на основе методики ФМЕА, позволяющей повысить качество оценки, сократить субъективность в принятии решений, делая прогноз на основе исторических данных, а не только субъективным опытом эксперта.

Анализ рисков; ФМЕА; машинное обучение; прогнозирование; система поддержки принятия решений.

E.S. Podoplelova, I.I. Knyazev

MODIFICATION OF THE FMEA METHOD USING MACHINE LEARNING ALGORITHMS

Risk assessment is an important task in any field, from manufacturing to medicine. Risks accompany a project, product or process throughout its life, from the moment of planning until its complete termination. Each of them has its own approaches. These include FMEA (Failure Mode and Effects Analysis) - analysis of the types and consequences of failures. The proposed model is based on the FMEA method, which is based on risk assessment according to three criteria: the severity of the consequences when a threat is realized and the complexity of identifying a failure, the probability of occurrence. The first two criteria are based on expert assessment obtained in accordance with artificial intelligence methods. The authors proposed a modification of the third criterion. In our work, we replaced the expert assessment of the "probability of occurrence" criterion with a machine learning model capable of predicting this indicator based on statistical data. We carried out the first stage of research into the task at hand on NASA's open dataset about engine operating cycles before failure. Initially, the task was set to predict the remaining number of cycles before failure, then we moved to the classification task, determining whether the equipment is at risk, depending on its potential remaining life. The best result was obtained by the support vector machine (SVM), with a classification accuracy of 80%. The goal of the work is to create a risk assessment model based on the FMEA methodology, which allows to improve the quality of assessment, reduce subjectivity in decision making, making a forecast based on historical data, and not just the subjective experience of an expert.

Risk assessment; FMEA; machine learning; forecasting; decision support system.

Введение. Оценка и управление рисками является важной частью любого процесса, следовательно, любая предметная область имеет свои методы и подходы. Впервые данная методология была предложена в стандарте США MIL-STD-1629 «Procedures for Performing a Failure Mode, Effects and Criticality Analysis», там дано следующее определение: FMEA – это процедура, с помощью которой проводится анализ всех возможных ошибок системы и определения последствий воздействия на систему с целью классификации всех ошибок по признаку их критичности для работы системы [1, 2].

В последствии методология приобрела широкую популярность в производственной сфере, причем не только в анализе конструкций, но и в анализе самих процессов. В работе [3] предложенный авторами метод тестировался на двух задачах в областях производства аэрокосмической электроники и стрелочной системы метро.

В работе [4] данный подход использовался для оценки рисков роботизированной реабилитации, причем не с технической точки зрения отказа оборудования, а с применением анализа среды функционирования (АСФ), которая включает оценку социальной и экономической стороны. Так же, в данной работе были применены методы многокритериального принятия решений, нечеткие множества, а также, для ранжирования ошибок по уровням опасности была применена кластеризация.

В работе [5] также применяется методика FMEA для оценки рисков в логистике. Предлагается система поддержки принятия решений (СППР), используется нечеткая логика и методы многокритериального принятия решений.

Все эти исследования объединяет цель получить такую систему, способную оценивать риски быстро и качественно, не уступая высококвалифицированному эксперту. Все они формализовали разницу в опыте и стаже экспертов (в случае участия группы экспертов), изменяли веса критериев, чтобы получить гибкую и наиболее объективную систему.

Описание метода. Традиционный FMEA включает три критерия: сложность определения дефекта (D), вероятность реализации угрозы (O) и тяжесть последствий (S). Мы предлагаем автоматизировать оценку вероятности реализации угрозы,

получая задачу прогнозирования отказа. Для этого необходимы статистические данные по объекту анализа, что является первой сложностью при реализации.

S - тяжесть последствий	O - вероятность отказа	D - сложность обнаружения
Экспертная оценка	Прогнозирование на основе исторических данных	Экспертная оценка

Рис. 1. Модификация модели FMEA

В рамках статьи будет рассмотрена только задача прогнозирования, описанная на примере отказа оборудования на данных NASA [6]. Этот набор данных представляет собой версию Kaggle очень общедоступного набора данных для моделирования деградации активов NASA. Он включает в себя смоделированные данные по работе до отказа турбовентиляторных реактивных двигателей.

Моделирование деградации двигателя проводилось с использованием C-MAPSS. Четыре разных набора были смоделированы при различных сочетаниях рабочих условий и режимов неисправности. Используются несколько каналов датчиков для характеристики развития дефектов.

Цель исследования состоит в том, чтобы спрогнозировать оставшийся срок службы каждого двигателя в наборе тестовых данных, то есть количество полетов (успешных запусков) после последней записи.

Анализ данных. Проанализировав данный набор, его можно описать следующим образом:

- ◆ 100 двигателей;
- ◆ 21 датчик;
- ◆ 3 режима работы
- ◆ 20631 запись (временная метка).

После анализа было выявлено, что настройка 3 не изменяема, т.е. не имеет никакого влияния на работу. Ряд показателей датчиков также статичен, а значит также не несет никакой полезной информации, способной повлиять на прогноз. Датчики под номерами 1, 5, 6, 10, 16, 18, 19 были исключены из дальнейшего исследования на втором и третьем этапах.

Далее, мы получили график, показывающий жизненный цикл каждого двигателя. На рис. 2 представлен фрагмент.




Рис. 2. Жизненный цикл первых 20-ти двигателей

Распределение длительности работы двигателей в количественном соотношении представлено на рис. 3.




Рис. 3. Распределение количества двигателей по длительности работы

Как видим, большинство двигателей работает в пределах 190–210, далее они начинают отказывать. После преобразований мы получили количество использований по каждому двигателю до отказа. Дальнейшей задачей является настройка методов машинного обучения. Исследование происходило в три этапа:

1. Тестирование со всеми параметрами без исторических данных.
2. Тестирование с исключение «бесполезных» датчиков и режимов без исторических данных.
3. Тестирование с исключение «бесполезных» датчиков и режимов с историческими данными.

Для анализа были выбраны методы: Random Forest [7, 8], Linear Regression [9, 10], SVM [11–13].

В результате первого (верхний график) и второго этапов (нижний график) мы выяснили, что модель прогнозирует срок службы значительно выше реального (рис. 4).




Рис. 4. Результат первого и второго этапов

На третьем этапе мы пытаемся обнаружить закономерности временных рядов в наших функциях, добавляя к имеющимся данным новую функцию, называемую «функция скользящего среднего». Это эквивалент среднего значения признака с учетом 10 временных циклов. Он будет рассчитан для каждой функции.

Здесь мы видим, что датчики s_9, s_11, s_12 и s_7 оказывают существенное влияние на целевую переменную (ЦП). Например, если оставить все остальные функции постоянными, мы заметим, что, когда физическая скорость ядра (представленная s_9) увеличивается, ЦП сравнительно уменьшается.

Судя по разнице в RMSE, мы замечаем, что SVR работает лучше, чем другие модели, при выполнении на всем наборе данных. Полученное тестовое RMSE равно 31, и это будет наш результат, который мы сможем превзойти при запуске модели с использованием лучших функций, обнаруженных на данный момент.

Далее, задача была сведена к классификации, где мы определили 3 класса:

1. Целевая переменная в диапазоне [0...68]: Зона риска, близится отказ оборудования.
2. Целевая переменная в диапазоне [69...137]: Средний уровень риска.
3. Целевая переменная в диапазоне [138...361]: Риска нет, прогнозируемое количество успешных запусков больше 138.

Результаты классификации разными методами представлены в табл. 1.

Таблица 1

Результаты классификации

SVM	Accuracy score of training	0.789
	Error rate of training	0.175
	Accuracy score of test	0.776
	Error rate of test	0.172
KNN[14]	Accuracy score of validation	0.620
	Error rate of validation	0.227
Random Forest	Accuracy score of validation	0.650
	Error rate of validation	0.207
Guassian Naive Bayes[15, 16]	Accuracy score of train	0.634
	Error rate of train	0.199
	Accuracy score of test	0.651
	Error rate of test	0.182

Как видно из таблицы, наилучший результат достигнут методом опорных векторов, однако, точность все еще далека от идеальной. Случайный лес, Наивный Байес изначально были сильно подвержены переобучению, в итоге так и не дали лучшей точности.

Заключение. В результате описанного исследования мы оценили модификацию FMEA методики методами машинного обучения и сделали следующие выводы: для получения высокой точности (более 90%) необходимо больше статистических данных, как можно больше приближенных к реальности. Также, планируется рассмотреть другие модели, например нейронные сети [17–19] и Леса с квантильной регрессией (QRF) [20–21].

Однако, в рамках целого исследования оценки рисков методом FMEA, остальные два критерия остаются для оценки специалистами. Представление знаний экспертов также является важной частью в разработке СППР, мы модифицировали только ту часть, которая, по нашему мнению, сможет обеспечить решение задачи прогнозирования в условиях отсутствия квалифицированного эксперта, потому что итоговое решение остаётся за ЛПП.

Полученные результаты уже имеют точность, способную сравниться с оценкой среднего специалиста, и, в то же время, даже превзойти ЛПП, не имеющего четкого представления и специальных знаний об объекте оценки, что в перспективе сможет решить проблему нехватки квалифицированных узконаправленных специалистов. Методы машинного обучения способны решить ряд описанных выше проблем, но полная замена человека не предполагается в ближайшие годы.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. *McDermott, Robin E., Mikulak, Raymond J., Beauregard Michael R.* The Basics of FMEA. – Productivity Press, 1996. – 80 p. – ISBN 9780527763206.
2. Анализ видов и последствий потенциальных отказов. FMEA. Ссылочное руководство: пер. с англ. четвёртого издания от июня 2008 г. – Н. Новгород: ООО СМЦ «Приоритет», 2012. – 282 с. (двуязычное). – ISBN 978-5-98366-042-7.
3. *Xiang-Kun Zhao, Xiao-Min Zhu, Kai-Yuan Bai, Run-Tong Zhang.* A novel failure model and effect analysis method using a flexible knowledge acquisition framework based on picture fuzzy sets // Engineering Applications of Artificial Intelligence. – 2023. – Vol. 117, Part A. – 105625.
4. *Jiawan Liu, Duojin Wang, Qinglian Lin, Meikui Deng.* Risk assessment based on FMEA combining DEA and cloud model: A case application in robot-assisted rehabilitation // Expert Systems with Applications. – 2023. – Vol. 214. – 119119.
5. *Nabil K. and Dkhissi P.B.* A decision support system for evaluating the logistical risks in Supply chains based on RPN factors and multi criteria decision making approach // 2022 IEEE 6th International Conference on Logistics Operations Management (GOL). Strasbourg, France, 2022. – P. 1-6.
6. Kaggle: NASA Turbofan Jet Engine Data Set. – URL: <https://www.kaggle.com/datasets/behrad3d/nasa-cmaps>.
7. *Hastie, T., Tibshirani R., Friedman J.* Chapter 15. Random Forests. The Elements of Statistical Learning: Data Mining, Inference, and Prediction. – 2nd ed. – Springer-Verlag, 2009. – 746 p.
8. Scikit-learn: Machine Learning in Python: Документация RandomForestClassifier. – URL: <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.RandomForestClassifier.html>.
9. *Deng H., Runger G., Tuv E.* Bias of importance measures for multi-valued attributes and solutions // Proceedings of the 21st International Conference on Artificial Neural Networks (ICANN). – 2011. – P. 293-300.
10. *Демиденко Е.З.* Линейная и нелинейная регрессия. – М.: Финансы и статистика, 1981. – 302 с.
11. *Alexander Statnikov, Constantin F. Aliferis, Douglas P. Hardin.* A Gentle Introduction to Support Vector Machines in Biomedicine: Theory and methods. – World Scientific, 2011.
12. *Nello Cristianini, John Shawe-Taylor.* An Introduction to Support Vector Machines and Other Kernel-based Learning Methods. – Cambridge University Press, 2000.
13. *Владимир Вьюгин.* Математические основы теории машинного обучения и прогнозирования. – МЦМНО, 2013. – 390 с.
14. *Madeh Piryonesi S., Tamer E. El-Diraby.* Role of Data Analytics in Infrastructure Asset Management: Overcoming Data Size and Quality Problems (англ.) // Journal of Transportation Engineering, Part B: Pavements. – 2020-06. – Vol. 146, Issue 2. – P. 04020022.
15. *Domingos, Pedro & Michael Pazzani.* On the optimality of the simple Bayesian classifier under zero-one loss // Machine Learning. – 1997. – 29. – P. 103-137.
16. Scikit-learn: Machine Learning in Python: Документация: Наивные методы Байеса. – URL: <https://scikit-learn.ru/1-9-naive-bayes/>.
17. Time Series Predictions with RNNs. – URL: <https://encord.com/blog/time-series-predictions-with-recurrent-neural-networks/>.
18. *Wong Ka, Wong Raymond.* An Efficient Risk Data Learning with LSTM RNN. – 2019.
19. *Hastie T., Tibshirani R., Friedman J.* The Elements of Statistical Learning. – 2nd ed. – Springer, 2009. – 533 p
20. *Nicolai Meinshausen.* Quantile Regression Forests // Journal of Machine Learning Research. – 2006. – P. 983-999.
21. *Wang Di, Wang Ping, Wang Cong, Wang Pingping.* Calibrating probabilistic predictions of quantile regression forests with conformal predictive systems // Pattern Recognition Letters. – 2022. – Vol. 156. – P. 81-87.

REFERENCES

1. *McDermott, Robin E., Mikulak, Raymond J., Beauregard Michael R.* The Basics of FMEA. – Productivity Press, 1996. – 80 p. – ISBN 9780527763206.
2. Analiz vidov i posledstviy potentsial'nykh otkazov. FMEA. Ssylochnoe rukovodstvo [Analysis of the types and consequences of potential failures. FMEA. Reference manual]: trans. from English fourth ed. dated June 2008. Nizhny Novgorod: OOO SMTS «Prioritet», 2012, 282 p. (bilingual). ISBN 978-5-98366-042-7.
3. *Xiang-Kun Zhao, Xiao-Min Zhu, Kai-Yuan Bai, Run-Tong Zhang.* A novel failure model and effect analysis method using a flexible knowledge acquisition framework based on picture fuzzy sets, *Engineering Applications of Artificial Intelligence*, 2023, Vol. 117, Part A, 105625.
4. *Jiawan Liu, Duojin Wang, Qinglian Lin, Meikui Deng.* Risk assessment based on FMEA combining DEA and cloud model: A case application in robot-assisted rehabilitation, *Expert Systems with Applications*, 2023, Vol. 214, 119119.
5. *Nabil K. and Dkhissi P.B.* A decision support system for evaluating the logistical risks in Supply chains based on RPN factors and multi criteria decision making approach, *2022 IEEE 6th International Conference on Logistics Operations Management (GOL). Strasbourg, France, 2022*, pp. 1-6.
6. Kaggle: NASA Turbofan Jet Engine Data Set. Available at: <https://www.kaggle.com/datasets/behrad3d/nasa-cmaps>.
7. *Hastie, T., Tibshirani R., Friedman J.* Chapter 15. Random Forests. The Elements of Statistical Learning: Data Mining, Inference, and Prediction. 2nd ed. Springer-Verlag, 2009, 746 p.
8. Scikit-learn: Machine Learning in Python: Documentation RandomForestClassifier. Available at: <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.RandomForestClassifier.html>.
9. *Deng H., Runger G., Tuv E.* Bias of importance measures for multi-valued attributes and solutions, *Proceedings of the 21st International Conference on Artificial Neural Networks (ICANN)*, 2011, pp. 293-300.
10. *Demidenko E.Z.* Lineynaya i nelineynaya regressiya [Linear and nonlinear regression]. Moscow: Finansy i statistika, 1981, 302 p.
11. *Alexander Statnikov, Constantin F. Aliferis, Douglas P. Hardin.* A Gentle Introduction to Support Vector Machines in Biomedicine: Theory and methods. World Scientific, 2011.
12. *Nello Cristianini, John Shawe-Taylor.* An Introduction to Support Vector Machines and Other Kernel-based Learning Methods. Cambridge University Press, 2000.
13. *Vladimir V'yugin.* Matematicheskie osnovy teorii mashinnogo obucheniya i prognozirovaniya [Mathematical foundations of the theory of machine learning and forecasting]. MTSMNO, 2013, 390 p.
14. *Madeh Piryonesi S., Tamer E. El-Diraby.* Role of Data Analytics in Infrastructure Asset Management: Overcoming Data Size and Quality Problems, *Journal of Transportation Engineering. Part B: Pavements*, 2020-06, Vol. 146, Issue 2, pp. 04020022.
15. *Domingos, Pedro & Michael Pazzani.* On the optimality of the simple Bayesian classifier under zero-one loss, *Machine Learning*, 1997, 29, pp. 103-137.
16. Scikit-learn: Machine Learning in Python: Dokumentatsiya: Naivnye metody Bayesa [Scikit-learn: Machine Learning in Python: Documentation: Naive Bayes methods]. Available at: <https://scikit-learn.ru/1-9-naive-bayes/>.
17. Time Series Predictions with RNNs. Available at: <https://encord.com/blog/time-series-predictions-with-recurrent-neural-networks/>.
18. *Wong Ka, Wong Raymond.* An Efficient Risk Data Learning with LSTM RNN, 2019.
19. *Hastie T., Tibshirani R., Friedman J.* The Elements of Statistical Learning. 2nd ed. Springer, 2009, 533 p.
20. *Nicolai Meinshausen.* Quantile Regression Forests, *Journal of Machine Learning Research*, 2006, pp. 983-999.
21. *Wang Di, Wang Ping, Wang Cong, Wang Pingping.* Calibrating probabilistic predictions of quantile regression forests with conformal predictive systems, *Pattern Recognition Letters*, 2022, Vol. 156, pp. 81-87.

Статью рекомендовал к опубликованию д.т.н., профессор Н.Е. Сергеев.

Подоплелова Елизавета Сергеевна – Южный федеральный университет; e-mail: chuzhinova@sfnedu.ru; г. Таганрог, Россия; тел.: +79525844188; аспирант.

Князев Иван Игоревич – e-mail: ikniazev@sfnedu.ru; тел.: +79265347104; аспирант.

Podoplelova Elizaveta Sergeevna – Southern Federal University; e-mail: chuzhinova@sfnedu.ru; Taganrog, Russia; phone: +79525844188; postgraduate student.

Knyazev Ivan Igorevich – e-mail: ikniazev@sfnedu.ru; phone: +79265347104; postgraduate student.

УДК 004.932.4

DOI 10.18522/2311-3103-2023-6-95-104

К.О. Север, Д.А. Гужва, И.И. Турулин

РЕКУРСИВНЫЙ РАЗДЕЛИМЫЙ ДВУМЕРНЫЙ ЦИФРОВОЙ ФИЛЬТР ДЛЯ ПОВЫШЕНИЯ РЕЗКОСТИ RGB-ИЗОБРАЖЕНИЙ

Важную роль в восприятии качества изображения играет резкость, то есть величина градиента яркости в областях вблизи границ объектов. Данная характеристика отвечает за четкость и детализацию мелких элементов изображения. Расфокусировка объектива камеры и недостаточная освещенность являются основными факторами, которые могут привести к размытию цифрового изображения. Для увеличения резкости используют различные методы обработки, такие как фильтрация в частотной области, например применение быстрого преобразования Фурье для подчеркивания границ и текстур изображения. Применение данного типа фильтрации позволяет управлять контрастом и частотным содержанием изображения, что приводит к улучшению визуального восприятия. Однако данный метод имеет ряд существенных недостатков, таких как логарифмическая сложность и выполнение дополнительных вычислений, связанных с прямым и обратным преобразованием Фурье. Поэтому предпочтительным методом повышения резкости изображения является так называемая пространственная обработка, обеспечивающая прямую фильтрацию пикселей изображения без дополнительных преобразований, а повторное использование результатов обработки (рекурсивной составляющей) в фильтре позволяет сократить число операций, уменьшить вычислительную сложность. В статье описана разработка эффективного рекурсивного разделимого двумерного цифрового фильтра для повышения резкости RGB-изображений большой размерности. Приведены алгоритмы его построения, спроектированы соответствующие структурные схемы. Фильтр обладает свойством более равномерной детализации объектов изображения, и менее подвержен созданию импульсного шума. Также для исходного RGB-изображения высокого разрешения смоделирован фильтр размытия, матрица которого заполняется по нормальному (гауссовому) закону. Для оценки качества фильтрации разработанный фильтр сравнивается с алгоритмом классической двумерной свертки с ядром фильтра высоких частот Лапласа 5x5.

Обработка изображений; двумерные цифровые фильтры; рекурсивные алгоритмы; резкость; фильтр; двумерный; изображение.

K.O. Sever, D.A. Guzhva, I.I. Turulin

RECURSIVE SEPARABLE 2D DIGITAL FILTER FOR INCREASING THE SHARPNESS OF RGB IMAGES

An important role in the perception of image quality is sharpness, that is, the magnitude of the brightness gradient in areas near the boundaries of objects. This characteristic is responsible for the clarity and detail of small image elements. Defocusing the camera lens and insufficient illumination are the main factors that can lead to digital image blurring. To increase the sharpness, various processing methods are used, such as filtering in the frequency domain, for example, the use of fast Fourier transform to emphasize the boundaries and textures of the image. The use of this type